

Suvremena psihologija 17 (2014), 2, 125-136

Izvorni znanstveni članak - UDK 159.922.2

PROVJERA MODELA PREDVIĐANJA AKADEMSKOG POSTIGNUĆA STUDENATA: ULOGA PROAKTIVNOSTI I PRISTUPA UČENJU

Gabrijela Vrdoljak

Odsjek za psihologiju, Filozofski fakultet
Sveučilište J. J. Strossmayera u Osijeku
Lorenza Jägera 9, 31000 Osijek
gabrijela_p_hr@yahoo.com

Marija Kristek

Odjel za matematiku
Sveučilište J. J. Strossmayera u Osijeku
Trg Ljudevita Gaja 6, 31000 Osijek
mkristek@mathos.hr

Ana Jakopec

Odsjek za psihologiju, Filozofski fakultet
Sveučilište J. J. Strossmayera u Osijeku
Lorenza Jägera 9, 31000 Osijek
ajakopec1@ffos.hr

Predrag Zarevski

Odsjek za psihologiju, Filozofski fakultet Sveučilišta u Zagrebu
Ivana Lučića 3, 10000 Zagreb
pzarevsk@ffzg.hr

Sažetak

Cilj je istraživanja provjeriti doprinos proaktivnosti i različitih pristupa učenju akademskom postignuću studenata. Nadalje, provjerava se i medijacijska uloga različitih pristupa učenju (dubinskog, površinskog i strateškog) u odnosu proaktivnosti i akademskog postignuća. Podaci su prikupljeni anketiranjem većeg prigodnog uzorka studenata diplomskih studija različitih usmjerenja i obrađeni path analizom u okviru strukturalnog modeliranja. U skladu s pretpostavkama modela, rezultati potvrđuju pozitivan utjecaj proaktivnosti na dubinski i strateški pristup učenju, odnosno negativnu povezanost proaktivnosti i površinskog pristupa učenju. Nadalje, strateški pristup učenju pozitivno doprinosi akademskom postignuću studenata, dok površinski pristup negativno doprinosi istom. Dubinski pristup učenju nema direktan efekt na akademsko postignuće studenata, međutim, dubinski pristup učenju, indirektno, putem strateškog pristupa, pozitivno utječe na akademsko postignuće. Također, rezultati su potvrdili i posredujući utjecaj strateškog i površinskog pristupa učenju u odnosu proaktivnosti i akademskog postignuća, odnosno pokazali kako proaktivnost studenata indirektno,

putem navedenih pristupa učenju pozitivno doprinosi akademskom postignuću studenata. Preciznije, veći stupanj proaktivnosti rezultirat će odabirom učinkovitijih pristupa učenju, a samim time i višim akademskim postignućem studenata. Nalazi istraživanja interpretiraju se u okviru teorije samoreguliranog učenja i koncepta studentskog pristupa učenju. Raspravlja se o važnosti i načinima implementacije dobivenih rezultata u akademskom kontekstu.

Ključne riječi: proaktivnost, pristupi učenju, akademsko postignuće

UVOD

U kontekstu današnjeg društva, akademsko postignuće sve je značajnije. Unatoč velikom broju istraživanja, sama definicija, kao i odrednice akademskog postignuća i dalje su nejasne (Robbins, Lauver, Davis, Langley i Carlstrom, 2004). Postignuće se obično operacionalizira kao uspjeh na standardiziranim testovima znanja. Najčešće korištene mjere akademskog postignuća su prosječna ocjena tijekom studija, uspjeh na točno određenom testu ili na standardiziranim testovima znanja (Kalechstein i Nowicki, 1997; Sinkavich, 1994). Akademsko postignuće funkcija je individualnih razlika, a konstrukti koji bi ga mogli predviđati su mnogobrojni. Ranija istraživanja provjeravala su doprinos kognitivnih i motivacijskih varijabli, osobina ličnosti, obilježja studija, obiteljske te socijalne okoline studenta, vještina, navika te pristupa učenju u predviđanju akademskog (ne)uspjeha studenata. Najčešće povezane individualne osobine s akademskim postignućem su inteligencija i osobine ličnosti. Strenze (2007) u skupini sudionika u dobi između 20 i 24 godine nalazi slabiju povezanost između inteligencije i akademskog postignuća. Chamorro-Premuzic i Furnham (2008) također pronalaze nisku povezanost testova inteligencije i akademskog postignuća. Nadalje, osobine ličnosti su se također pokazale značajnim prediktorima akademskog postignuća. Hakimi, Hejazi i Lavasani (2011) su osobinama ličnosti studenata bihevioralnih znanosti objasnili 48% varijance akademskog postignuća. Ipak, uzevši u obzir isključivo razinu visokog obrazovanja, meta-analize upućuju na *savjesnost* kao jedini relevantan prediktor akademskog postignuća (Poropat, 2009; Trapmann, Hell, Hirn i Schuler, 2007). Iako su kognitivne i osobinske varijable značajni prediktori akademskog postignuća, znatan dio varijance tog kriterija ostaje neobjašnjen. Uz pristupe učenju, u tu je svrhu u ovom istraživanju u prediktorski skup uključena i proaktivnost.

Proaktivnost i akademsko postignuće

Bateman i Crant (1993) proaktivno ponašanje definiraju u dispozicijskim terminima, odnosno kao ponašanje osobe koje direktno mijenja (utječe na) okolinu. Drže kako postoji razlika između pojedinaca koji mijenjaju svijet i onih koji mu se prilagođavaju. Proaktivni pojedinci aktivno traže prilike, pokazuju inicijativu, poduzimaju aktivnosti i ustraju u njima dok ne postignu željeni cilj (Harré, 1983).

Konstrukat proaktivne ličnosti istraživana je uglavnom u okviru organizacijske psihologije. Crant (2000) nalazi povezanost između proaktivnosti i uspjeha u radu, karijeri, rukovođenju te poduzetništvu. Iako proaktivnost nije u velikoj mjeri istraživana u okviru psihologije odgoja i obrazovanja, karakteristike koje Crant (2000) navodi ujedno su značajne i za objašnjenje akademskog postignuća: proaktivna ličnost, iskazivanje osobne inicijative, preuzimanje odgovornosti i samoeфикаsnost u velikom broju uloga. Zimmermanova (1990) teorija samoreguliranog učenja, razvijena u okviru socio-kognitivnog modela, naglašava da samoregulirano učenje uključuje proaktivno zalaganje i traženje prilika za učenje. Wang, Cullen, Yao i Li (2013) su ispitivali odnos proaktivnosti i akademskog postignuća studenata. Proaktivnost je uključivala tri faktora: traženje povratne informacije, izgradnja odnosa s autoritetom, te druženje s kolegama. Značajnim za prosječnu ocjenu na studiju pokazao se faktor traženja povratne informacije, a za uključivanje u studentske aktivnosti faktor druženja s kolegama.

Pristupi učenju i akademsko postignuće

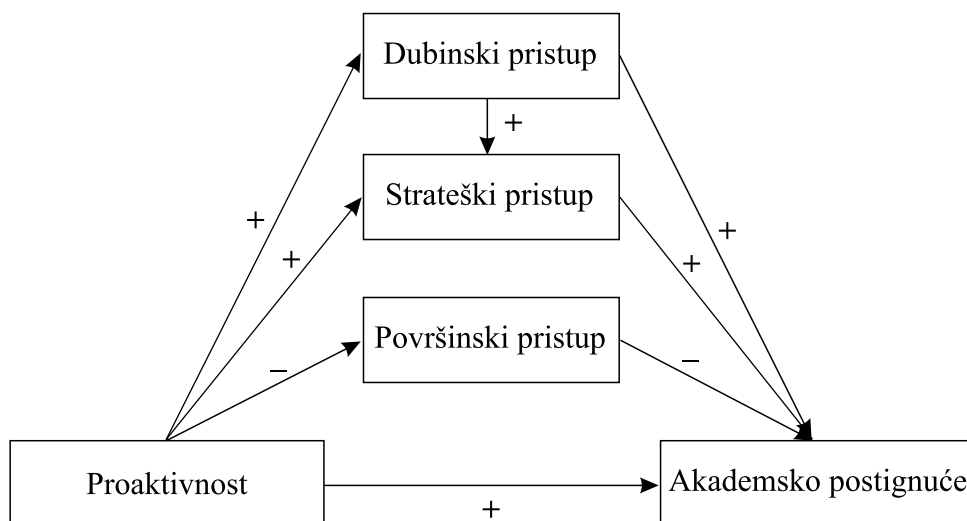
U okviru koncepta studentskog pristupa učenju, Biggs (1987) razlikuje tri pristupa: dubinski, površinski i strateški. Studenti koji dubinski pristupaju učenju su intrinzično motivirani, osobni interes i uživanje vide kao svrhu učenja, aktivno traže smisao u onome što uče te povezuju novo naučeno s već postojećim znanjem. Studenti koji površinski pristupaju učenju su uglavnom ekstrinzično motivirani, učenjem nastoje izbjeći neuspjeh, pamte te reproduciraju materijale bez povezivanja gradiva ili traženja smisla u onome što uče. Studenti koji strateški pristupaju učenju su usmjereni na postizanje uspjeha i dobivanje dobrih ocjena, odabiru optimalne strategije, zalažu se za pronalaženje optimalnih materijala i uvjeta za učenje (Gaderlab, 2011). Iz opisa različitih pristupa učenju opravdano je očekivati značajnu vezu između pristupa učenju i akademskog postignuća. Istraživanje Rosandera i Bäckströma (2012) pokazalo je da uz kontrolu faktora inteligencije i osobina ličnosti, pristupi učenju objašnjavaju 6% varijance akademskog postignuća djevojaka i 16% varijance kod mladića. Rezultati istraživanja povezanosti različitih pristupa učenju i akademskog postignuća nisu dosljedni. Wilding i Valentine (1972) su pronašli značajnu pozitivnu povezanost samo između strateškog pristupa učenju i uspjeha na ispitu znanja. Diseth i Martinsen (2003) navode strateški pristup kao pozitivan, a površinski pristup učenju kao negativan prediktor akademskog postignuća. Istovremeno, upućuju na vrlo nisku povezanost dubinskog pristupa učenju i akademskog postignuća. Chamorro-Premuzic i Furnham (2008) dobivaju značajnu pozitivnu povezanost između ocjene na ispitu znanja i dubinskog pristupa učenju, značajnu pozitivnu, ali nešto nižu povezanost sa strateškim pristupom, te nepostojanje povezanosti s površinskim pristupom. Slične rezultate dobio je i Gaderlab (2011). Bakhtiarvand, Ahmadian, Delrooz i Farahani (2011) upućuju na značajnu pozitivnu povezanost dubinskog, te značajnu negativnu povezanost površinskog

pristupa učenju i akademskog postignuća. Rodriguez (2009) smatra da akademsko postignuće studenata može biti rezultat kombiniranja različitih pristupa učenju studenata. Rezultati njegova istraživanja pokazali su da dubinski pristup učenju, upravo preko strateškog, najpovoljnije djeluje na akademsko postignuće studenata.

Budući da dosadašnja razmjerno rijetka istraživanja nisu došla do čvrstih zaključaka, *cilj* je ovog istraživanja provjeriti doprinos proaktivnosti i različitih pristupa učenju akademskom postignuću studenata. Nadalje, provjerava se i medijacijska uloga različitih pristupa učenju (dubinskog, površinskog i strateškog) u odnosu proaktivnosti i akademskog postignuća studenata.

Pretpostavljeni model i razvoj hipoteza

Pretpostavljeni model prikazan na slici 1 provjerava ulogu proaktivnosti i pristupa učenju u predviđanju akademskog postignuća studenata. Model se djelomice temelji na postojećoj literaturi, ali ju i proširuje uvođenjem konstrukta proaktivnosti. S obzirom na to da proaktivnost predviđa samoregulirano učenje studenata (Sidelinger, 2010), motivaciju za učenje (Major, Turner i Fletcher, 2006) te utječe na kvalitetu učenja (Kickul i Kickul, 2006), pretpostavlja se da će imati učinke i na odabir pristupa učenju. Također, sukladno istraživanju Wang i sur. (2013) pretpostavljen je i direktan pozitivan doprinos proaktivnosti akademskom postignuću. Prema rezultatima dosadašnjih istraživanja (primjerice, Diseth i Martinsen, 2003; Gaderlab, 2011) pretpostavlja se da će strateški i dubinski pristup učenju pozitivno



Slika 1. Pretpostavljeni model uloge proaktivnosti i pristupa učenju u predviđanju akademskog postignuća

doprinositi akademskom postignuću studenata, dok će površinski pristup negativno doprinositi istom. Dosljedno rezultatima istraživanja Rodrigueza (2009), pretpostavlja se da će dubinski pristup učenju i indirektno, putem strateškog pristupa, pozitivno doprinositi akademskom postignuću studenata te da će navedeni indirektan efekt ujedno biti izraženiji od svih direktnih efekata pristupa učenju na akademsko postignuće studenata. Stoga se može očekivati i posredujući efekt pristupa učenju u odnosu između proaktivnosti i akademskog postignuća studenata.

METODA

Sudionici i postupak

U istraživanju je sudjelovalo ukupno 255 studenata (81,2% žena) prve godine diplomskog studija Ekonomskog fakulteta, Filozofskog fakulteta, Odjela za matematiku te Odjela za fiziku Sveučilišta Josipa Jurja Strossmayera u Osijeku prosječne dobi od 22,44 godina ($SD = 1,48$). Istraživanje je provedeno anonimno i dobrovoljno unutar približno 20 minuta.

Instrumenti

Mjera pristupa i vještina učenja studenata (prilagođen prema *Approaches and Study Skills Inventory for Students – ASSIST*; Entwistle, 1997) korištena je u svrhu procjene pristupa učenju studenata. Sastoji se od tri dijela. Prvi dio se odnosi na vlastito shvaćanje pojma “učenje” studenata. Drugi dio se sastoji od 52 čestice podijeljene u tri subskale, u svrhu mjerenja tri glavna pristupa učenju: *dubinskog* (16 čestica; primjerice “Jedan od ciljeva učenja koje si uobičajeno postavljam jest razumjeti smisao onoga što učim”), *strateškog* (20 čestica; primjerice “Pažljivo razmatram povratne informacije nastavnika kako bih sljedeći put dobio/la bolju ocjenu”) i *površinskog* (16 čestica; primjerice “Čini mi se da se trebam dosta koncentrirati da bih samo upamtio/la ono što učim”). Tvrdnje su procjenjivane na ljestvicama Likertova tipa s pet stupnjeva: od 1 = *nikako se ne slažem* do 5 = *u potpunosti se slažem*. Treći dio mjeri sklonosti različitim vrstama poučavanja. U ovom je istraživanju korišten samo drugi dio mjere. Rezultati konfirmatorne faktorske analize potvrdili su trofaktorsku strukturu korištenog dijela mjere. Indeksi slaganja upućuju na zadovoljavajuće slaganje pretpostavljenog modela s podacima (χ^2 [df = 1216; N = 255] = 2153.6, $p < 0,001$; NC = 1,77; SRMR = 0,04; GFI = 0,95; AGFI = 0,94; CFI = 0,94; NFI = 0,90; RMSEA = 0,05). Pri tome sve čestice imaju zasićenja odgovarajućim faktorom u rasponu od 0,63 do 0,85.

Upitnik proaktivnosti P1 (Zarevski, Sladić i Vranić, 2001) prilagođen je za potrebe ovog istraživanja. Sastoji se od 28 tvrdnji na koje se odgovara s “Da” ili “Ne”, ovisno o tome koliko smatra da tvrdnja opisuje njegovo ponašanje. Čestice upitnika ciljaju na dvije facete proaktivnosti: *Sklonost promjeni* (primjerice “Pokrećem pro-

mjene u najužoj okolini”) i *Sklonost planiranju* (primjerice “Barem desetak dana prije puta provjerim nije li mi putovnica istekla”). U ovom je istraživanju korišten ukupan rezultat kao mjera proaktivnosti.

Akademsko postignuće je određeno kao prosječan uspjeh studenata na preddiplomskom studiju.


REZULTATI I RASPRAVA

U tablici 1 prikazane su aritmetičke sredine, standardne devijacije, Cronbach alpha koeficijenti i interkorelacije svih mjerenih varijabli.

Tablica 1. Aritmetičke sredine, standardne devijacije, Cronbach alpha koeficijenti i korelacije svih mjerenih varijabli

	Deskriptivna statistika			Korelacije			
	<i>M</i>	<i>SD</i>	α	2	3	4	5
1. Proaktivnost	44,79	4,02	0,68	0,35**	0,41**	-0,25**	0,04
2. Dubinski pristup	58,62	8,39	0,83		0,43**	-0,21**	0,02
3. Strateški pristup	72,48	12,13	0,80			-0,07	0,22**
4. Površinski pristup	51,95	9,67	0,79				-0,14*
5. Akademsko postignuće	3,58	0,60	-				

Napomena. *N* = 255. ** $p < 0,01$, * $p < 0,05$



Slika 2. Model predviđanja akademskog postignuća studenata

Path analiza unutar strukturalnog modeliranja korištena je u svrhu procjene podudarnosti pretpostavljenog modela prikazanog na slici 1 s podacima. U svrhu procjene stupnja podudarnosti pretpostavljenog modela s podacima korišteni su sljedeći pokazatelji: Hi kvadrat test, CFI (*Comparative fit index*), NFI (*Normed-fit index*), RMSEA (*Root mean square error of approximation*), GFI (*Goodness-of-fit statistic*), AGFI (*Adjusted goodness-of-fit statistic*) te SRMR (*Standardised root mean square residual*).

Budući da se povezanost proaktivnosti i akademskog postignuća nije pokazala statistički značajnom, dovodi se u pitanje opravdanost provjeravanja posredujućeg efekta pristupa učenju u odnosu između navedenih varijabli. Naime, Baron i Kenny (1986) navode tri kriterija koja moraju biti zadovoljena da bi se moglo govoriti o posredujućem efektu: mora postojati značajna povezanost (1) prediktora i kriterija te (2) prediktora i medijatora te također (3) medijator mora biti značajan prediktor ishoda u jednadžbi koja uključuje oboje, i medijator i prediktor. Ipak, rezultati novijih istraživanja (Hayes, 2009; MacKinnon, Krull i Lockwood, 2000; Rucker, Preacher, Tormala i Petty 2011; Zhao, Lynch i Chen, 2010) upućuju na (i eksperimentalne) dokaze o postojanju značajnog indirektnog efekta, čak i u odsutnosti značajnog direktnog, odnosno ukupnog efekta, te time dovode u pitanje zahtjeve Barona i Kenny-a (1986). Autori navedenih istraživanja smatraju da ispitivanje indirektnih efekata treba biti vođeno teorijom te predlažu njihovo istraživanje i provjeravanje neovisno o značajnosti direktnih, odnosno ukupnih efekata. U suprotnom, može doći do pogrešne interpretacije podataka i onemogućavanja širenja teorija i akumuliranja znanja. Iz navedenih razloga i u ovom će se radu provjeriti pretpostavljeni indirektni efekt.

Neznačajan χ^2 test te vrijednosti CFI, GFI i NFI $\geq 0,95$ pokazatelj su zadovoljavajuće podudarnosti pretpostavljenog modela s podacima $\geq 0,95$ (Hooper, Cougblan i Mullen, 2008). Vrijednosti AGFI i TLI pokazatelja koje upućuju na zadovoljavajuću podudarnost pretpostavljenog modela s podacima trebale bi biti više od 0,90 (Miles i Shevlin, 1998). Gornje ograničenje preporučene RMSEA vrijednosti je 0,08 (Byrne, 1998). Vrijednosti SRMR manje od 0,05 pokazatelj su zadovoljavajuće podudarnosti modela s podacima (Byrne, 1998). Rezultati svih pokazatelja upućuju na vrlo dobru podudarnost pretpostavljenog modela s podacima (χ^2 [df = 2; N = 255] = 5,63, $p = 0,06$; SRMR = 0,03; GFI = 0,99; AGFI = 0,94; CFI = 0,97; NFI = 0,96; RMSEA = 0,08).

U skladu s pretpostavkama i korelacijskom matricom, standardizirani parametri modela potvrdili su pozitivan doprinos proaktivnosti dubinskom ($\beta = 0,34$, $p < 0,01$) i strateškom ($\beta = 0,29$, $p < 0,01$), a negativan doprinos površinskom pristupu učenju ($\beta = -0,24$, $p < 0,01$). Dakle, proaktivniji će studenti biti skloniji češće koristiti učinkovitije pristupe učenju (dubinski i strateški). Ovakvi su nalazi očekivani, s obzirom na opis obrasca ponašanja proaktivnih studenata (Zarevski, Marušić i Vranić, 2002), koji najviše odgovara upotrebi strateškog pristupa učenju, budući je njegova glavna odrednica namjera za ostvarivanje postavljenih ciljeva. Također, kako je proaktivno učenje jedna od glavnih odrednica samoreguliranog učenja (Zimmerman, 1990),

koje omogućuje dublje procesiranje informacija i bolje razumijevanje materijala, veza između proaktivnosti i dubinskog pristupa učenju također je očekivana.

Korištenje strateškog pristupa učenju pozitivno doprinosi akademskom postignuću studenata ($\beta = 0,27, p < 0,01$), dok površinski pristup učenju negativno djeluje na isto ($\beta = -0,15, p < 0,05$). Dakle, ekstrinzična motiviranost, minimalno ulaganje napaora s ciljem izvršavanja nužnih aktivnosti, bez većeg razumijevanja sadržaja i smislenog učenja, uz istaknut strah od neuspjeha doprinijet će slabijem akademskom postignuću, dok će namjera za ostvarivanjem postavljenih ciljeva – u kontekstu akademskog postignuća, pri čemu pojedinci pronalaze i stvaraju povoljne unutarne i vanjske uvjete za učenje, doprinijeti višem akademskom postignuću. Direktni efekt dubinskog pristupa učenju na akademsko postignuće studenata nije se pokazao statistički značajnim. Značajnost indirektnog efekta dubinskog pristupa učenju na akademsko postignuće studenata provjerena je Monte–Carlo metodom aproksimacije (*bootstrapping*-om). Rezultati su pokazali kako dubinski pristup učenju samo indirektno, putem strateškog pristupa, pozitivno doprinosi akademskom postignuću studenata ($\beta = 0,08, p < 0,01$). Ipak, suprotno očekivanjima, kao i nalazima Rodrigueza (2009), ovaj efekt je slabo izražen. Dakle, intrinzična motivacija za usvajanjem i povezivanjem sadržaja s postojećim znanjima i iskustvima, te nadograđivanjem i produblјivanjem vlastitih spoznaja putem dalјnjih neobveznih istraživanja (dubinski pristupa) neće direktno doprinijeti boljem akademskom postignuću, već samo indirektno, putem strateškog pristupa.

Dobiveni nalazi u skladu su s nalazima prethodno navedenih istraživanja (Chamorro-Premuzic i Furnham, 2008; Diseth i Kobbeltvedt, 2010; Diseth i Martinsen, 2003; Liem, Lau i Nie, 2008; López, Cerveró, Rodríguez, Félix i Esteban, 2013). S obzirom na sličnost i povezanost odrednica dubinskog i strateškog pristupa, indirektni doprinos dubinskog pristupa učenju akademskom postignuću studenata također je očekivan. Dakle, studenti koji teže razumijevanju sadržaja te povezivanju i proširivanju znanja, a uz to odabiru optimalne strategije, materijale i uvjete za učenje, imat će veće akademsko postignuće u odnosu na one koji su isključivo intrinzično motivirani za učenje.

Nadalje, značajnost posredujuće uloge pristupa učenju u odnosu proaktivnosti i akademskog postignuća također je provjerena Monte–Carlo metodom aproksimacije. Rezultati su potvrdili posredujući učinak pristupa učenju u odnosu proaktivnosti i akademskog postignuća ($\beta = 0,11, p < 0,01$), odnosno pokazali kako proaktivnost studenata *upravo indirektno*, putem pristupa učenju pozitivno doprinosi njihovu akademskom postignuću. Navedeni posredujući odnos, prema našim saznanjima, do danas nije istraživao. Ipak, dobiveni rezultati ne iznenađuju, već pružaju i empirijsku potvrdu posredujuće uloge pristupa učenju u odnosu proaktivnosti i akademskog postignuća. Naime, rezultati su pokazali kako će veći stupanj proaktivnosti rezultirati odabirom učinkovitijih pristupa učenju, a samim time i višim akademskim postignućem studenata.

Provedeno istraživanje ima i određene nedostatke. Prvo, sam nacrt istraživanja ne omogućuje zaključivanje o kauzalnom odnosu među ispitivanim konstruktima, što otvara mogućnost alternativnih interpretacija rezultata. Drugo, s obzirom na to da su svi podaci prikupljeni metodom samoprocjene u istom vremenskom periodu te iz istih izvora, postoji mogućnost učinka zajedničke varijance metode (Podsakoff, MacKenzie, Lee i Podsakoff, 2003). Za provjeru efekta zajedničke varijance metode najčešće se koristi Harman post-hoc jedno-faktorski test (Podsakoff i Organ, 1986). Eksploratornom faktorskom analizom svih čestica ispitivanih varijabli izdvojeno je 29 faktora sa svojstvenim vrijednostima većim od 1, koji ukupno objašnjavaju 70% varijance. Najveći postotak zajedničke varijance objašnjen pojedinačnim faktorom iznosio je 11%, što je znatno manje od kriterija 50%, te se može odbaciti objašnjenje rezultata učinkom zajedničke varijance.

Nalazi ovog istraživanja imaju teorijske, ali i važne praktične implikacije. Zbog porasta i jačanja konkurencije na tržištu rada, pred studente se postavljaju sve veća očekivanja, zahtjevi i pritisci, u svrhu povećanja njihove zapošljivosti. Uspješnost studenata sve je više strukturirana komponentama samostalno vođenog planiranja, učenja, istraživanja, ali prije svega preuzimanja kontrole i poticanja samoinicijative u svrhu pomicanja vlastitih granica znanja, iskustava i novih izazova. To su ujedno i komponente proaktivne ličnosti, koje konceptualno podupiru pojam zapošljivosti (Fugate, Kinicki i Ashforth, 2004). Na proaktivnost utječu individualne razlike, situacijski faktori kao i njihova međusobna interakcija (Parker, Williams i Turner, 2006), što znači da je proaktivno ponašanje studenata djelomice u funkciji njih kao osoba, a djelomice u funkciji njihova (obrazovnog) okruženja. Dakle, obrazovni sustav trebao bi poticati i pružati pozitivnu, podržavajuću klimu usmjerenu na osnaživanje studenata u preuzimanju kontrole i poticanju samoinicijative, pri čemu ne bi trebalo zanemariti ni aktivnu ulogu pristupa nastavnika i samog odnosa prema radu. To bi doprinijelo razvijanju proaktivnog ponašanja studenata i odabiru učinkovitijih pristupa učenju te postizanju višeg akademskog postignuća, što bi se odrazilo na njihovu konkurentnost i zapošljivost.

LITERATURA

- Bakhtiarvand, F., Ahmadian, S., Delrooz, K., Farahani, H.A. (2011). The Moderating Effect of Achievement Motivation on Relationship of Learning Approaches and Academic Achievement. *Procedia – Social and Behavioral Sciences*, 28, 486-488.
- Baron, R.M., Kenny, D.A. (1986). The moderator–mediator variable distinction in social psychological research: Conceptual, strategic, and statistical considerations. *Journal of Personality and Social Psychology*, 51, 1173.
- Bateman, T.S., Crant, J.M. (1993). The proactive component of organizational behavior. *Journal of Organizational Behavior*, 14, 103-118.
- Biggs, J. (1987). *Study process questionnaire manual*. Hawthorne: Australian Council for Educational Research.

- Byrne, B.M. (1998). *Structural Equation Modeling with LISREL, PRELIS and SIMPLIS: Basic Concepts, Applications and Programming*. Mahwah, New Jersey: Lawrence Erlbaum Associates.
- Chamorro-Premuzic, T., Furnham, A. (2008). Personality, intelligence and approaches to learning as predictors of academic performance. *Personality and Individual Differences*, 44, 1596-1603.
- Crant, J.M. (2000). Proactive behavior in organizations. *Journal of Management*, 26, 435-462.
- Diseth, Å., Martinsen, Ø. (2003). Approaches to Learning, Cognitive Style, and Motives as Predictors of Academic Achievement. *Educational Psychology*, 23, 195-207.
- Diseth, Å., Kobbeltvedt, T. (2010). A mediation analysis of achievement motives, goals, learning strategies, and academic achievement. *British Journal of Educational Psychology* 80, 671-687.
- Entwistle, N.J. (1997). The approaches and study skills inventory for students (ASSIST). *Edinburgh: Centre for Research on Learning and Instruction, University of Edinburgh*.
- Fugate, M., Kinicki, A.J., Ashforth, B.E. (2004). Employability: A psycho-social construct, its dimensions, and applications. *Journal of Vocational Behavior*, 65, 14-38.
- Furnham, A., Chamorro-Premuzic, T. (2004). Personality and intelligence as predictors of statistics examination grades. *Personality and Individual Differences*, 37, 1013-1022.
- Gadelrab, H.F. (2011). Factorial structure and predictive validity of approaches and study skills inventory for students (ASSIST) in Egypt: A confirmatory factor analysis approach. *Electronic Journal of Research in Educational Psychology*, 9, 1197-1218.
- Hakimi, S., Hejazi, E., Lavasani, M. G. (2011). The Relationships Between Personality Traits and Students' Academic Achievement. *Procedia – Social and Behavioral Sciences*, 29, 836-845.
- Harré, R. (1983). *Personal being: A theory for individual psychology*. Oxford: Blackwell.
- Hayes, A.F. (2009). Beyond Baron and Kenny: Statistical mediation analysis in the new millennium. *Communication Monographs*, 76, 408-420.
- Hooper, D., Coughlan, J., Mullen, M. (2008). Structural Equation Modelling: Guidelines for Determining Model Fit. *Electronic Journal of Business Research Methods*, 6, 53-60.
- Kalechstein, A.D., Nowicki, Jr., S. (1997). A meta-analytic examination of the relationship between control expectancies and academic achievement: An 11-yr follow-up to Findeley and Cooper. *Genetic, Social, and General Psychology Monographs*, 123, 27-56.
- Kickul, G., Kickul, J. (2006). Closing the gap: impact of student proactivity and learning goal orientation on e-learning outcomes. *International Journal on E-learning*, 5, 361-372.
- Liem, A.D., Lau, S., Nie, Y (2008). The role of self-efficacy, task value, and achievement goals in predicting learning strategies, task disengagement, peer relationship, and achievement outcome. *Contemporary Educational Psychology*, 33, 486-512.
- López, B.G., Cerveró, G.A., Rodríguez, J.M.S., Félix, E.G., Esteban, P.R.G. (2013). Learning styles and approaches to learning in excellent and average first-year university students. *European journal of psychology of education*, 28, 1361-1379.
- MacKinnon, D.P., Krull, J.L., Lockwood, C.M. (2000). Equivalence of the mediation, confounding, and suppression effect. *Prevention Science*, 1, 173-181.

- Major, D.A., Turner, J.E., Fletcher, T.D. (2006). Linking proactive personality and the Big Five to motivation to learn and development activity. *Journal of Applied Psychology*, 91, 927.
- Miles, J., Shevlin, M. (1998). Effects of sample size, model specification and factor loadings on the GFI in confirmatory factor analysis. *Personality and Individual Differences*, 25, 85-90.
- Parker, S.K., Williams, H.M., Turner, N. (2006). Modeling the antecedents of proactive behavior at work. *Journal of Applied Psychology*, 91, 636-652.
- Podsakoff, P.M., MacKenzie, S.B., Lee, J.Y., Podsakoff, N.P. (2003). Common method biases in behavioral research: A critical review of the literature and recommended remedies. *Journal of Applied Psychology*, 88, 879-903.
- Podsakoff, P.M., Organ, D.W. (1986). Self-reports in organizational research: Problems and prospects. *Journal of Management*, 12, 531-544.
- Poropat, A. E. (2009). A meta-analysis of the five-factor model of personality and academic performance. *Psychological bulletin*, 135, 322.
- Robbins, S.B., Lauver, K., Le, H., Davis, D., Langley, R., Carlstrom, A. (2004). Do Psycho-social and Study Skill Factors Predict College Outcomes? A Meta-Analysis. *Psychological Bulletin*, 130, 261-288.
- Rodriguez, C.M. (2009). The impact of academic self-concept, expectations and the choice of learning strategy on academic achievement: the case of business students. *Higher Education Research & Development*, 28, 523-539.
- Rosander, P., Bäckström, M. (2012). The unique contribution of learning approaches to academic performance, after controlling for IQ and personality: Are there gender differences? *Learning and Individual Differences*, 22, 820-826.
- Rucker, D.D., Preacher, K.J., Tormala, Z.L., Petty, R.E. (2011). Mediation analysis in social psychology: Current practices and new recommendations. *Social and Personality Psychology Compass*, 5, 359-371.
- Sidelinger, R.J. (2010). College student involvement: An examination of student characteristics and perceived instructor communication behaviors in the classroom. *Communication Studies*, 61, 87-103.
- Sinkavich, F.J. (1994). Metamemory, attributional styles, and study strategies: Predicting classroom performance in graduate studies. *Journal of Instructional Psychology* 21, 172-182.
- Strenze, T. (2007). Intelligence and socioeconomic success: A meta-analytic review of longitudinal research. *Intelligence*, 35, 401-426.
- Trapmann, S., Hell, B., Hirn, J.O.W., Schuler, H. (2007). Meta-analysis of the relationship between the Big Five and academic success at university. *Zeitschrift für Psychologie (Journal of Psychology)*, 215, 132-151.
- Wang, Y., Cullen, K.L., Yao, X., Li, Y. (2013). Personality, freshmen proactive social behavior, and college transition: Predictors beyond academic strategies. *Learning and Individual Differences*, 23, 205-212.
- Wilding, J., Valentine, E. (1972). Factors predicting success and failure in the first year examinations of medical and dental courses. *Applied Cognitive Psychology*, 6, 247-261.
- Zarevski, P., Marušić, A., Vranić, A. (2002). Proaktivnost i lokus kontrole u menadžera. *Društvena istraživanja*, 11, 659-680.

- Zarevski, P., Sladić, I., Vranić, A. (2001). Proaktivnost – predstavljanje i evaluacija konstrukta. *Suvremena psihologija*, 4, 73-92.
- Zhao, X., Lynch, J.G., Jr, Chen, Q. (2010). Reconsidering Baron and Kenny: Myths and truths about mediation analysis. *Journal of Consumer Research*, 37, 197-206.
- Zimmerman, B.J. (1990). Self-Regulated Learning and Academic Achievement: An Overview. *Educational Psychologist* 25, 3-17.

VERIFYING THE MODEL OF STUDENTS' ACADEMIC ACHIEVEMENT PREDICTION: THE ROLE OF PROACTIVITY AND LEARNING APPROACHES

Summary

The aim of this empirical research is to verify the contribution of proactivity and different learning approaches to students' academic achievement. Furthermore, it investigates the mediating role of different learning approaches (deep, surface and strategic) in the relationship between proactivity and academic achievement. Data was collected by surveying a large sample of undergraduate students of different orientations and analyzed with path analysis within the structural equations modeling. In line with the assumptions of the proposed model, the results confirm the positive impact of proactivity on deep and strategic learning approaches and a negative relationship between proactivity and use of surface learning approach. Furthermore, a strategic approach positively contributes to the students' academic achievement, while the surface approach has a negative contribution. The deep learning approach has no direct effect on the students' academic achievement. However, the deep approach, through the strategic approach, indirectly positively affects students' academic achievement. Also, the results confirmed the mediating role of strategic and surface learning approaches in the relationship between proactivity and academic achievement, which demonstrates that students' proactivity, indirectly, through these learning approaches, positively contributes to the students' academic achievement. Specifically, higher degree of proactivity will result in selecting effective learning approaches, which will further lead to a higher level of students' academic achievement. The research findings are interpreted in the framework of the theory of self-regulated learning and the concept of students' approaches to learning. The importance and ways of implementation of the results in an academic context are discussed.

Key words: proactivity, learning approaches, academic achievement

Primljeno: 30. 06. 2014.